

# Klasické metody redukce dimenze dat

1. Připomenutí PCA (Principal Component Analysis, rozklad na hlavní komponenty)
2. ICA (Independent Component Analysis, rozklad na nezávislé komponenty)  
[Jutten & Héroult 1991]
3. Fisherova lineární diskriminační analýza (FLDA)

## Literatura k tématu

- [1] R.O. Duda – P.E. Hart – D.G. Stork. Pattern Classification. John Wiley & Sons, 2001.
- [1] A. Hyvärinen – E. Oja. Independent Component Analysis: Algorithms and Applications. *Neural Networks*, 13(4-5):411-430, 2000.

# PCA: Rozklad na hlavní komponenty

Máme množinu bodů  $\mathbf{x}_1, \dots, \mathbf{x}_k$  v prostoru dimenze  $d$ , z bodů vytvoříme  $d \times k$  matici  $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_k]$

Hledáme nejlepší reprezentaci  $\mathbf{X}$  v prostoru dimenze  $s < d$

$$\mathbf{X} = (x_1, x_2, x_3)$$


1. Nejlepší reprezentace pro  $s = 0$  minimalizuje energii

$$J_0(\mathbf{x}_0) = \sum_{i=1}^k \|\mathbf{x}_i - \mathbf{x}_0\|^2,$$

kde řešením je

$$\mathbf{x}_0 = \frac{1}{k} \sum_{i=1}^k \mathbf{x}_i \quad \text{důkaz: } \textcircled{*}1$$


$d \times k$   $k \times d$



- pozn:  $\mathbf{X}\mathbf{X}^T$  je  $d \times d$  kovarianční matice  $\sum_{i=1}^k \mathbf{x}_i \mathbf{x}_i^T$

# PCA: pokračování

2. Nejlepší reprezentace při  $s = 1$  je průmět na přímku



$$y_i = x_0 + t_i w, \quad \text{kde } w \text{ je vektor dimenze } d \text{ a } \|w\| = 1$$

*vezměme!*

Parametry  $t_i, i = 1, 2, \dots, k$  a  $w$  minimalizují energii

$$J(t_1, \dots, t_k, w) = \sum_{i=1}^k \|x_0 + t_i w - x_i\|^2 = \sum_i \|t_i w - \bar{x}_i\|^2 = \sum_i (t_i w - \bar{x}_i)^T (t_i w - \bar{x}_i) =$$

$$= \sum_{i=1}^k (t_i^2 - 2t_i w^T \bar{x}_i + \bar{x}_i^T \bar{x}_i)$$

*$2t_i - 2w^T \bar{x}_i = 0$*

z  $\frac{\partial J}{\partial t_i} = 0$  dostaneme  $t_i = w^T \bar{x}_i = \bar{x}_i^T w$ . Po dosazení

$$J(t_1, \dots, t_k, w) = \dots = \sum_{i=1}^k \bar{x}_i^T \bar{x}_i - w^T \left( \sum_i \bar{x}_i \bar{x}_i^T \right) w = \sigma^2 - w^T S w,$$

*$- w^T \bar{x}_i \bar{x}_i^T w + \bar{x}_i^T x_i$*

*$Q = w^T S w + \lambda (w^T w - 1)$*

*nutná:  $S w = \lambda w$*

*avg max  $w^T S w$   
 $\|w\|^2 = 1$*

kde  $S$  je  $d \times d$  kovarianční matice  $S = X X^T$

# PCA: pokračování


Hledáme minimum  $J$  za podmínky  $\|\mathbf{w}\|^2 = 1$

$$\mathbf{w}^* = \arg \min_{\mathbf{w}} (\sigma^2 - \mathbf{w}^\top \mathbf{S} \mathbf{w} + \lambda(\mathbf{w}^\top \mathbf{w} - 1))$$

z  $\frac{\partial J}{\partial \mathbf{w}} = 0$  dostaneme  $2\mathbf{S}\mathbf{w} - 2\lambda\mathbf{w} = 0$ , z čehož plyne


$\mathbf{w}$  musí být vlastním vektorem  $\mathbf{S} = \mathbf{X}\mathbf{X}^\top$  odpovídajícím největšímu vlastnímu číslu.

3. při  $s > 1$  postupujeme obdobně, promítáme do  $s$ -dimenzionální nadroviny



$$\mathbf{y}_i = \mathbf{x}_0 + \sum_{j=1}^s t_i^j \mathbf{w}^j \quad s < d$$

a zjistíme, že  $\mathbf{w}^j$  jsou rovny **ortogonálním vlastním vektorům**  $\mathbf{S}$  odpovídající  $s$  největším vlastním číslům.



# Vlastnosti PCA

- vybíráme komponenty v pořadí energie (rozptylu)
- komponenty jsou nekorelované (po odečtení střední hodnoty  $\mathbf{x}_0$ ):

$$(t_i^m \mathbf{w}^m)^\top (t_i^n \mathbf{w}^n) = t_i^m t_i^n (\mathbf{w}^m)^\top \mathbf{w}^n = \begin{cases} t_i^{2n} & \text{pro } m = n \\ 0 & \text{jinak} \end{cases}$$

- aby metoda měla smysl, kovarianční matice má mít plnou hodnost, tedy  $k > d$
- pokud nás zajímá ‚signál‘ promítнутý do  $s$  hlavních komponent PCA, pak

$$\mathbf{y} = \mathbf{W}^\top (\mathbf{x} - \mathbf{x}_0),$$

*Handwritten annotations:  $s \times k + d \times s$  above  $\mathbf{W}^\top$ ,  $d \times k$  above  $(\mathbf{x} - \mathbf{x}_0)$*

kde  $\mathbf{W}$  je  $d \times s$  matice hlavních komponent  $\mathbf{W} = [\mathbf{w}^1, \mathbf{w}^2, \dots, \mathbf{w}^s]$   <sup>$d \times s$</sup>  po sloupcích

- komponenty  $\mathbf{w}^j$  jsou „vzorové signály“, lineární filtry s velkou odezvou na data podobná předloženým interpretace viz příklad na str. 7

# Rekonstrukce signálu z PCA

- rekonstrukce původního signálu je, po jednotlivých vektorech  $\mathbf{x}_j^*$

$$\mathbf{x}_j^* = \sum_{m=1}^s \mathbf{w}^m \alpha_m, \quad \text{kde} \quad \alpha_m = (\mathbf{w}^m)^\top (\mathbf{x}_j - \mathbf{x}_0)$$

Karhunen-Loève

- po přepsání

$$\mathbf{x}_j^* = \left[ \sum_{m=1}^s \mathbf{w}^m (\mathbf{w}^m)^\top \right] (\mathbf{x}_j - \mathbf{x}_0) = \mathbf{P} (\mathbf{x}_j - \mathbf{x}_0),$$





- $\mathbf{P} = \mathbf{W}\mathbf{W}^\top$  je singulární  $d \times d$  matice hodnosti  $s$
- nulový prostor  $\mathbf{P}$  odpovídá potlačeným složkám signálu
- $\mathbf{P}$  je tzv. „projekční matice“ :  $\mathbf{P}^2 = \mathbf{P}$
- rekonstrukce  $\mathbf{P}(\mathbf{x}_j - \mathbf{x}_0) + \mathbf{x}_0$  je „filtrováný signál“
- PCA minimalizuje energii rezidua  $\mathbf{x}^* - (\mathbf{x} - \mathbf{x}_0) \otimes 1$


# Aplikace: Eigenfaces

2901 snímků  $19 \times 19$  pixelů:


data laskavostí MIT <http://www.ai.mit.edu/projects/cbcl>




$x_0$




$x_0 + \alpha w^1$




$x_0 + \alpha w^2$




$x_0 + \alpha w^3$




$x_0 + \alpha w^4$




$x_0 + \alpha w^5$




$x_0 + \alpha w^6$




$x_0 + \alpha w^7$




$x_0 + \alpha w^8$




$x_0 + \alpha w^9$





$x_0 + \alpha w^{10}$




$x_0 + \alpha w^{11}$




$x_0 + \alpha w^{12}$




$x_0 + \alpha w^{13}$




$x_0 + \alpha w^{14}$




$x_0 + \alpha w^{15}$



$x_0 + \alpha w^{16}$



$x_0 + \alpha w^{17}$




$x_0 + \alpha w^{18}$

- průměry do vybraných komponent jsou příznaky k rozpoznání tváří od ,netváří'
- pro klasifikátor nutný (ruční) výběr komponent, které nemodelují osvětlení

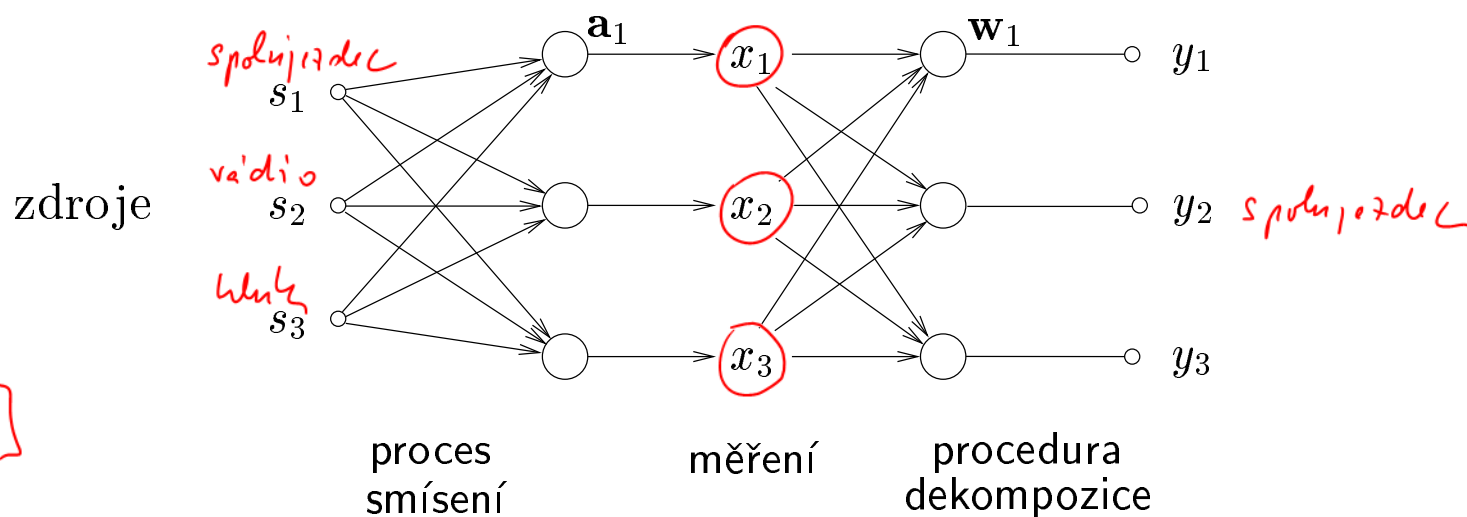
$P(x-y_0)+y_0$

- redukce z dimenze 361 do nižší potlačí šum; rekonstrukce prvního příkladu z 18 komponent:
- dobrý klasifikátor vyžaduje též PCA všech ,netváří'



# Rozklad na nezávislé komponenty

Předpokládáme, že měření  $x_i$  je neznámou směsí signálu z malého (známého) počtu neznámých nezávislých zdrojů  $\mathbf{s} = [s_1, \dots, s_s]^\top$ , tj.  $x_i = \mathbf{a}_i^\top \mathbf{s}$



$$\mathbf{X} = [x_1, \dots, x_k]$$

dim 3

- hledáme komponenty  $y_i = \mathbf{w}_i^\top \mathbf{X}$  tak, aby měly vlastnosti původních složek  $s_i$

$$\mathbf{y} = \mathbf{W}^\top \mathbf{X} = \mathbf{W}^\top \mathbf{A}^\top \mathbf{s}$$

$\mathbf{W}$  bude 'inverzí'  $\mathbf{A}$

- nebude možné určit rozptyl  $s_i$ , protože  $x_i = \mathbf{a}_i^\top \mathbf{s} = \mathbf{a}_i^\top \sigma \frac{1}{\sigma} \mathbf{s}$
- $\Rightarrow$  komponenty nebudou mít 'pořadí' jako v PCA
- Jak poznat  $\mathbf{s}$ ? Nezávislost  $\mathbf{s} \Rightarrow$  nezávislost  $\mathbf{y}$
- **Postup:** hledání  $\mathbf{W}$  tak, aby  $\mathbf{y}$  byly nezávislé



# Rozklad na nezávislé komponenty: ICA

## Co můžeme dostat?

1. pomocí PCA dostaneme nekorelované složky, ale ne nezávislé, protože když místo  $x_i = \sum_j a_{ij}s_j$  bude  $x_i = \sum_j a_{ij}f(s_j)$ , tak dostaneme jiné řešení
2. zdroje musí být negausovské náhodné proměnné, protože ortogonální transformace  $\mathbf{R}$  gausovské náhodné proměnné je gausovská a u normálního rozdělení je nekorelovanost a nezávislost totéž  $x_i = \mathbf{a}_i^\top \mathbf{s} = \mathbf{a}_i^\top \mathbf{R}^\top \mathbf{R} \mathbf{s} \Rightarrow$  ,nepoznáme své komponenty‘
  - $\Rightarrow$  nelze použít PCA, protože předpokládá normalitu
  - negausovské rozdělení má vyšší momenty než do 2. řádu

# ICA: míra nezávislosti

Hledáme  $y_i = \mathbf{w}_i^\top \mathbf{X}$  tak, aby  $y_i$  byly navzájem nezávislé, tj, aby platilo

$$p(y_1, \dots, y_s) = \prod_{i=1}^s p(y_i)$$

Pokud jsou  $y_i$  nezávislé, platí

tento vzorec pro  $h_i(p) = \log(p)$  známe z vlastností entropie

$$E\{h_1(y_1) \cdot h_2(y_2) \cdots h_s(y_s)\} = \prod_{i=1}^s E\{h_i(y_i)\}$$

Vhodnou mírou nezávislosti je vzájemná informace

$$I(y_1, \dots, y_s) = \sum_{i=1}^s H(y_i) - H(y_1, \dots, y_s)$$

## pokračování

Problém  $y_i = \mathbf{w}_i^\top \mathbf{X}$ ,  $i = 1, 2, \dots, s$  lze zapsat v maticovém tvaru  $\mathbf{y} = \mathbf{W}^\top \mathbf{X}$ , kde  $\mathbf{W}$  je matice  $s \times d$

Pokud  $\mathbf{y} = \mathbf{W}^\top \mathbf{X}$ , tak platí

$$I(y_1, \dots, y_s) = \sum_i H(y_i) - \cancel{H(x_1, \dots, x_k)} - \log \det \mathbf{W}$$

protože

$$y_i = \mathbf{w}_i^\top \mathbf{X}$$

$$H(y_1, \dots, y_s) = \iint f(y_1, \dots, y_s) \log f(y_1, \dots, y_s) dy_1 \cdots y_s = \iint f(\mathbf{x}) \log \frac{f(\mathbf{x})}{\det \mathbf{W}} d\mathbf{x}$$

Když  $y_i$  budou mít jednotkovou kovarianční matici, tak

$$1 = \det \mathbf{I} = \det \mathbf{y}\mathbf{y}^\top = \det (\mathbf{W}^\top \mathbf{X}\mathbf{X}^\top \mathbf{W}) = (\det \mathbf{W})^2 \det \mathbf{X}\mathbf{X}^\top$$

takže  $\det \mathbf{W}$  je konstanta. Z toho plyne, že

$$I(y_1, \dots, y_s) = C + \sum_{i=1}^s H(y_i)$$

# ICA: aproximace kritériální funkce

Hledáme tedy  $\mathbf{w}_i$  tak, že


$$\mathbf{W}^* = \arg \min_{\mathbf{W}} \sum_{i=1}^s H(\mathbf{w}_i^\top \mathbf{X}), \quad \text{kde } \mathbf{w}_i \text{ jsou řádky matice } \mathbf{W}^\top$$

Z výpočetních důvodů se entropie  $H(u) = E\{-\log(u)\}$  aproximuje funkcí

$$J(y) = (E\{G(y)\} - E\{G(\nu)\})^2,$$

kde  $\nu \sim N(0, \mathbf{I})$  a typické volby jsou

$$G_1(u) = \frac{1}{a_1} \log \cosh a_1 u \quad \text{nebo} \quad G_2(u) = -e^{-a_2 \frac{u^2}{2}}$$



$$a_1 = a_2 = 1$$

$G(u) = u^2$  nelze použít, protože ,nerozpozná' nezávislost od nekorelovanosti

# Procedura ICA

## Postup pro $s = 1$

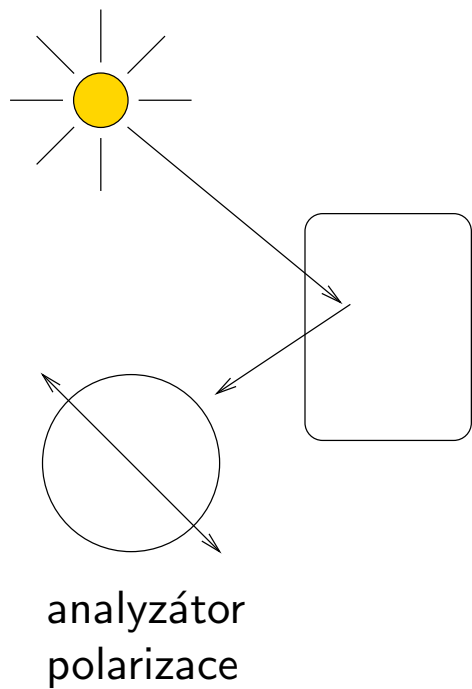
1. normalizuj data  $\bar{\mathbf{x}}_i := \mathbf{S}^{-\frac{1}{2}}(\mathbf{x}_i - \mathbf{x}_0)$  pro  $i = 1, 2, \dots, k$ ,  
kde  $\mathbf{S} = \sum_{i=1}^k (\mathbf{x}_i - \mathbf{x}_0)(\mathbf{x}_i - \mathbf{x}_0)^\top$  je kovarianční matice a  $\mathbf{S} = \mathbf{S}^{\frac{1}{2}} \mathbf{S}^{\frac{1}{2}}$  ,bělení'  
Choleski
2. zvol ~~náhodný~~ <sup>libovolný</sup> vektor  $\mathbf{w}$  tak, aby  $\|\mathbf{w}\| = 1$
3. necht'  $\mathbf{w}^+ = \sum_{i=1}^k \bar{\mathbf{x}}_i G'(\mathbf{w}^\top \bar{\mathbf{x}}_i) - G''(\mathbf{w}^\top \bar{\mathbf{x}}_i) \mathbf{w}$  Newtonovská iterace
4. renormalizuj  $\mathbf{w} = \frac{\mathbf{w}^+}{\|\mathbf{w}^+\|}$
5. opakuj kroky 3–4 do konvergence
6. nalezená komponenta je  $y = \mathbf{w}^\top \bar{\mathbf{X}}$   $y$  je vektor délky  $k$

odvození nutné podmínky pro minimum (proměnná je  $\mathbf{w}$ )

nutná podmínka pro  $J(\mathbf{w}^\top \mathbf{x}) \rightarrow$  nutná podmínka pro  $E\{G(\mathbf{w}^\top \mathbf{x})\}$  za podmínky  $\|\mathbf{w}\|^2 = 1$ .

- dobrá implementace je podstatně složitější

# Aplikace ICA: separace odlesků



vstupní obrazy

$x_1$




$x_2$



$x_3$




komponenta  $y_1$



komponenta  $y_2$



komponenta  $y_3$



- rovina polarizace závisí na úhlu normály  $\Rightarrow$  pohyb odlesku
- 3. komponenta částečně obsahuje tento pohyb

Konec

# spektrum

